

WYKORZYSTANIE INFORMACJI NA TEMAT AKTYWNOŚCI UŻYTKOWNIKA DO ZWIĘKSZENIA DOKŁADNOŚCI W ULTRASZEROKOPASMOWYM SYSTEMIE LOKALIZACYJNYM USING INFORMATION ON USER'S ACTIVITY TO IMPROVE ACCURACY IN AN ULTRA-WIDEBAND POSITIONING SYSTEM

Krystian Mandecki¹; Marcin Kołakowski²

Instytut Radioelektroniki i Technik Multimedialnych, Politechnika Warszawska, Warszawa

¹ krystian.mandecki.stud@pw.edu.pl ² marcin.kolakowski@pw.edu.pl

Streszczenie: W referacie zaprezentowano metodę lokalizacji przeznaczoną do wykorzystania w ultraszerokopasmowym systemie lokalizacyjnym. Metoda, oprócz prowadzenia pomiarów w interfejsie radiowym, zakłada ciągle monitorowanie aktywności użytkownika co, w połączeniu z informacją na temat rozkładu pomieszczenia, pozwala uzyskać dodatkowy kontekst. W zaproponowanej metodzie, użytkownik jest lokalizowany za pomocą filtru cząsteczkowego. Dodatkowy kontekst jest wykorzystywany na etapie ponownego próbkowania poprzez zwiększenie wag cząsteczek znajdujących się w obszarach, w których można wykonywać wykrytą aktywność.

Abstract: The paper presents a localization method intended for use in an ultra-wideband positioning system. The method, besides performing measurements in the radio interface, monitors the user's activity, which combined with the indoor area layout results in an additional positioning context. In the proposed method, the user is located using a particle filter. The additional context is used to increase the weights of particles located in the areas, where the detected activity can be performed.

Słowa kluczowe: detekcja aktywności, lokalizacja, uczenie głębokie, UWB

Keywords: activity detection, deep learning, positioning, UWB

1. WPROWADZENIE

W ostatnich latach obserwowany jest znaczący wzrost liczby zastosowań radiowych systemów lokalizacyjnych. Na rynku można znaleźć wiele rozwiązań pozwalających na świadczenie różnych usług opartych na lokalizacji np. nawigacji w centrach handlowych lub monitorowaniu procesu produkcji. Poprawna realizacja usług wymaga zapewnienia wyników lokalizacji o wystarczającej dokładności.

Dokładność wyników lokalizacji zależy od kilku czynników, z którym głównym jest technika wykorzystywana przez system. W systemach bazujących na pomiarach poziomu sygnału w interfejsach WiFi lub Bluetooth typowa dokładność jest rzędu pojedynczych metrów. Dużo lepsze wyniki zapewnia wykorzystanie techniki ultraszerokopasmowej, w której mierzone są czasy nadejścia

sygnałów. Pozwala ona na uzyskanie dokładności na poziomie kilkunastu centymetrów.

Drugim istotnym czynnikiem są warunki propagacyjne, w których pracuje system. Największe dokładności uzyskiwane są w warunkach LoS (ang. Line of Sight), w których bezpośrednia ścieżka między lokalizowaną etykietą a węzłami infrastruktury nie jest przysłonięta żadnymi przeszkodami. Niestety, zapewnienie takich warunków pracy w środowiskach wewnątrzbudynkowych jest niezwykle trudne ze względu na dużą liczbę przeszkód oraz ograniczoną liczbę węzłów infrastruktury. W typowych scenariuszach system przez większość czasu pracuje w warunkach NLoS (ang. Non Line of Sight). Problem ten jest szczególnie widoczny w systemach lokalizacji osób, w których ciało użytkownika wprowadza dodatkowe tłumienie i opóźnienie powodujące błędy lokalizacji na poziomie pojedynczych metrów [1].

Jednym ze sposobów redukcji błędów lokalizacji użytkownika jest zastosowanie algorytmów uwzględniających informacje o kontekście lokalizacji. W typowych rozwiązaniach algorytm dokonuje klasyfikacji aktywności użytkownika i wykorzystuje tę wiedzę w celu poprawy dokładności. Przykładowo, wykrycie wchodzenia po schodach [2] lub otwierania drzwi [3] powoduje przyciągnięcie wyników lokalizacji odpowiednio do obszaru klatki schodowej lub przejścia między pomieszczeniami.

Detekcja aktywności użytkownika może być przeprowadzana na podstawie danych otrzymanych z noszonych czujników inercyjnych [4]. Do pozyskania informacji dotyczącej wykonywanej przez człowieka aktywności stosuje się różne podejścia. Jednym z nich jest zastosowanie modeli uczenia maszynowego takich jak drzewa decyzyjne czy maszyny wektorów nośnych uczonych na wstępnie przetworzonych danych [5, 6]. Okazuje się jednak, że odpowiednie wytrenowanie głębokiej sieci neuronowej nawet bez wstępnego przetworzenia danych może skuteczniej wykrywać aktywność człowieka [7, 8]. Szczególnie skuteczne okazuje się zastosowanie głębokich spłotowych sieci neuronowych [9, 10] lub głębokich rekurencyjnych sieci neuronowych [11].

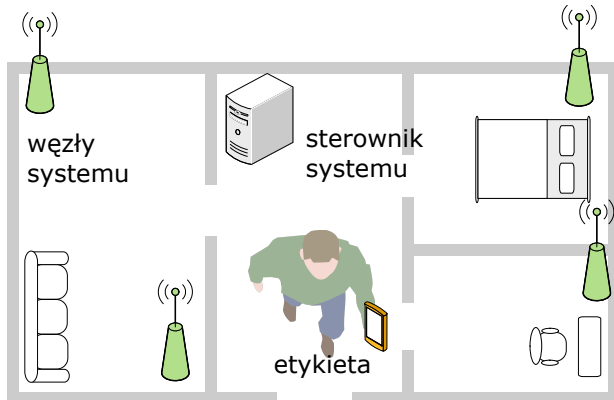
W referacie zaproponowano metodę lokalizacji, w której uwzględniany jest typ aktywności wykonywanej przez użytkownika (pozycja siedząca lub marsz). Do detekcji aktywności zastosowano spłotową sieć neuronową przetwarzającą dane z trzyosiowego akcelerometru. Infor-

macja na temat aktywności jest wykorzystywana w algorytmie filtru do zwiększenia wag cząsteczek znajdujących się w obszarze, w którym można wykonywać wykrytą aktywność.

2. KONCEPCJA METODY

2.1 Architektura systemu

Schemat funkcjonalny architektury systemu, w którym może zostać zastosowana zaproponowana metoda została przedstawiony na Rys. 1.



Rysunek 1: Architektura funkcjonalna systemu lokalizacyjnego

System składa się z trzech części: etykiety, węzłów oraz sterownika systemu. Etykieta jest niewielkim urządzeniem noszonym przez użytkownika. W zaproponowanym systemie pełni ona rolę źródła sygnału i okresowo nadaje pakiety UWB, które są odbierane przez węzły infrastruktury. Węzły mierzą czasy przybycia pakietów i przesyłają wyniki do sterownika systemu, w którym wyznaczana jest lokalizacja użytkownika.

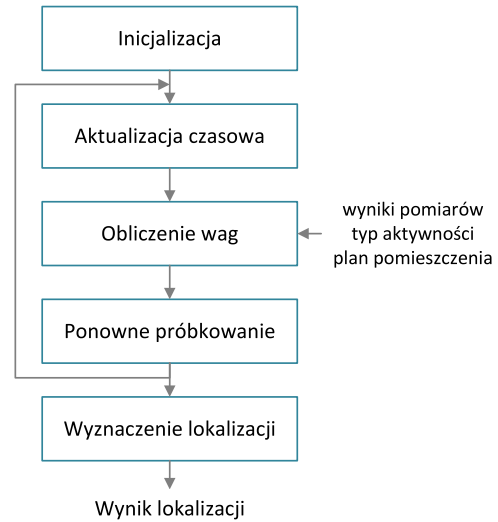
W zaproponowanym rozwiązaniu etykieta jest dodatkowo wyposażona w akcelerometr, którego wskazania są wykorzystywane do określania typu aktywności użytkownika (np. marsz, pozycja siedząca). Docelowo, klasyfikacja aktywności przeprowadzana będzie za pomocą modelu uczenia maszynowego zaimplementowanego w etykiecie a jej wyniki umieszczane w polu danych pakietów UWB. W obecnej implementacji przetwarzanie jest realizowane po stronie sterownika systemu.

Dane na temat aktywności, w połączeniu z planem pomieszczenia, pozwalają na uzyskanie dodatkowych informacji na temat kontekstu lokalizacji i zwiększenie jej dokładności. Przykładowo, klasyfikacja aktywności użytkownika znajdującego się w sypialni jako leżenie wskazuje, że znajduje się on w łóżku. Informacja na temat kontekstu lokalizacji jest wykorzystywana w zaproponowanym algorytmie opartym na filtrze cząsteczkowym.

2.2 Algorytm lokalizacyjny

Zaproponowany algorytm lokalizacyjny wykorzystuje algorytm z grupy filtrów cząsteczkowych PF (ang. Particle Filters). Główną ideą algorytmów PF jest estymacja rozkładu prawdopodobieństwa zmiennej losowej (w tym przypadku lokalizacji użytkownika) na podstawie danych empirycznych (pomiarów wykonywanych przez system).

Poszukiwany rozkład jest modelowany za pomocą cząsteczek, którym przypisane są wagi odpowiadające prawdopodobieństwu ich wystąpienia. Schemat blokowy zaproponowanego algorytmu przedstawiono na Rys. 2.



Rysunek 2: Schemat blokowy algorytmu lokalizacyjnego

Działanie filtru cząsteczkowego rozpoczyna się od losowej inicjalizacji N cząsteczek, z których każda opisana jest wektorem opisującym stan, w którym chwili k znajduje się użytkownik:

$$\mathbf{x}_k^{(i)} = [x \ v_x \ y \ v_y] \quad (1)$$

gdzie x , y to współrzędne użytkownika, a v_x , v_y są składowymi jego wektora prędkości. Cząsteczki generowane są w sposób losowy w obszarze objętym działaniem systemu z założeniem rozkładu jednostajnego. Każdej cząsteczce przypisana jest waga w_i odpowiadająca prawdopodobieństwu jej wystąpienia.

Kolejnym etapem przetwarzania danych jest aktualizacja czasowa, w której stan użytkownika w obecnym momencie k jest estymowany na podstawie przyjętego modelu ruchu.

$$\mathbf{x}_k^{(i)} = \mathbf{F} \mathbf{x}_{k-1}^{(i)} + \mathbf{n}_{k-1} \quad (2)$$

gdzie \mathbf{F} jest macierzą zawierającą równania ruchu (w implementacji przyjęto model ruchu jednostajnego) a \mathbf{n}_{k-1} dodatkowym zaburzeniem o rozkładzie normalnym.

Wagi cząsteczek są uaktualniane na podstawie wyników pomiarów i detekcji aktywności.

$$w_i = \eta(w_{m,i} + w_{a,i})w_{g,i} \quad (3)$$

$$w_{m,i} = 1 / \left(c \sqrt{\frac{\sum_n (z_{k,n} - h_{k,n}(\mathbf{x}_k^{(i)}))^2}{\text{len}(z_k)}} \right) \quad (4)$$

$$w_{a,i} = 1/d(\mathbf{x}_k^{(i)}) \quad (5)$$

$$w_{g,i} = \begin{cases} 1, & \text{jeśli } \mathbf{x}_k^{(i)} \text{ w granicach pomieszczenia} \\ 0, & \text{w przeciwnym przypadku} \end{cases} \quad (6)$$

Na wagę przypisywaną cząsteczce składają się trzy czynniki związane z wynikami pomiarów ($w_{m,i}$), kontekstem lokalizacji $w_{a,i}$ oraz rozkładem pomieszczenia $w_{g,i}$. Wagi są skalowane za pomocą współczynnika η tak by wagi wszystkich cząsteczek sumowały się do jedności.

Czynnik związany z wynikami pomiarów (zapisanymi w wektorze pomiarowym z_k) jest obliczany jako pierwiastek średniej kwadratów różnicy między pomiarami zwracanymi przez system $z_{k,n}$ a odpowiadającymi im wartościami estymowanymi dla lokalizacji danej cząsteczki $h_{k,n}(x_k^{(i)})$. Otrzymana wartość jest skalowana poprzez przemnożenie przez prędkość światła c by dopasować jednostki między poszczególnych czynników.

Kontekst lokalizacji jest uwzględniany poprzez dodanie czynnika $w_{a,i}$ będącego odwrotnością dystansu do najbliższego obszaru, w którym możliwe jest wykonywanie wykrytej aktywności. W przypadku detekcji aktywności, do których nie są przypisane żadne szczególne obszary czynnik ten wynosi 0.

W niektórych przypadkach, część cząsteczek może znaleźć się poza obszarem objętym działaniem systemu (np. za ścianami zewnętrznymi budynków). Aby uniknąć błędów, takim cząsteczkom przypisywana jest zerowa waga poprzez przemnożenie przez $w_{g,i}$.

Wartości cząsteczek wraz z wagami reprezentują rozkład poszukiwanej zmiennej losowej. Ostatnim krokiem przetwarzania danych jest ponowne próbkowanie polegające na celu zastąpienie cząsteczek nowymi, lepiej odpowiadającymi otrzymanemu rozkładowi. Otrzymane cząsteczki są wykorzystywane w kolejnej iteracji algorytmu.

Lokalizacja użytkownika obliczana jest jako średnia ważona cząsteczek:


$$x_k = \frac{\sum_i w_i x_k^{(i)}}{\sum_i w_i} \quad (7)$$

2.3 Moduł detekcji aktywności

Noszony przez człowieka akcelerometr odczytuje wartości przyspieszeń na każdej z osi 50 razy na sekundę. Ponadto, dla każdego z 3 odczytów przyspieszeń a_x, a_y, a_z w jednej chwili czasowej, liczony jest moduł przyspieszenia r z następującego wzoru:

$$r = \sqrt{a_x^2 + a_y^2 + a_z^2} \quad (8)$$

Detekcja aktywności jest przeprowadzana za pomocą sieci splotowej na podstawie przyspieszeń a_x, a_y, a_z, r otrzymanych w ciągu ostatnich 2 sekund. Architektura zastosowanej sieci splotowej przedstawiono na Rys. 3.



Rysunek 3: Architektura sieci neuronowej

W zaproponowanym modelu sieci neuronowej, za ekstrakcję cech odpowiadają dwie warstwy splotowe, po


każdej z nich zastosowano maksymalizującą warstwę łączącą. Przed warstwą wyjściową zastosowano warstwę w pełni połączoną.

W każdej warstwie łączącej i w warstwie w pełni połączony zastosowano porzucanie. Przyjęto współczynnik porzucania równy 0,1. Użyta funkcja aktywacji w warstwach splotowych oraz warstwie w pełni połączony to ReLU. Warstwę wyjściową stanowi jeden neuron z sigmoidalną funkcją aktywacji. Model został zaimplementowany przy użyciu języka Python oraz biblioteki TensorFlow.

3. BADANIA EKSPERYMENTALNE

Zaproponowana metoda została zbadana eksperymentalnie w jednym z laboratoriów Instytutu Radioelektroniki i Technik Multimedialnych Politechniki Warszawskiej. W trakcie badań wykorzystano ultraszerokopasmowy system wykorzystujący technikę Time Difference of Arrival (TDoA) [12]. Plan laboratorium, wraz z lokalizacją węzłów został przedstawiony na Rys. 4.

Zastosowany system składał się z czterech węzłów rozmieszczonych na ścianach pomieszczenia oraz etykiety. Do pomiarów przyspieszenia, została wykorzystana aplikacja mobilna. W trakcie badań, zarówno telefon jak i smartfon były noszone w kieszeni. Sterownik systemu oraz smartfon były podłączone do internetu co pozwoliło na synchronizację pomiarów zwracanych przez smartfon i infrastrukturę.




Rysunek 4: Rozkład pomieszczenia i przykładowe wyniki lokalizacji

Eksperyment polegał na lokalizacji osoby przemieszczającej się po zdefiniowanej trajektorii i siadającej na trzech krzesłach zlokalizowanych w pomieszczeniu. Podczas eksperymentu, rejestrowane były czasy, w których osoba przechodziła przez kolejne wierzchołki trajektorii oraz siadała. Pozwoliło to na uzyskanie referencyjnych lokalizacji użytkownika (założono, że osoba poruszała się ze stałą prędkością wzdłuż poszczególnych odcinków trajektorii), które zostały wykorzystane do obliczenia błędu lokalizacji.

Osoba lokalizowana była za pomocą zaproponowanej metody oraz konwencjonalnego filtra cząsteczkowego, w którym kontekst lokalizacji nie był uwzględniany (waga $w_{a,i}$ zawsze była równa 0). Otrzymane wyniki zostały przedstawione na Rys. 4.

Wyniki uzyskane za pomocą zaproponowanej metody cechują się większą jakością niż w przypadku wykorzystania konwencjonalnego filtra cząsteczkowego. Przypisanie większych wag cząsteczkom znajdującym się w pobliżu krzesła w momentach gdy aktywność osoby klasyfikowana jest jako siedzenie pozwala na zwiększenie dokładności lokalizacji. Dokładniejsza estymacja rozkładu wektora stanu pozytywnie wpływa na jakość kolejnych wyników. Otrzymana trajektoria ruchu jest bliżej krzywej referencyjnej.

Dokładniejsze porównanie metod można przeprowadzić na podstawie błędu lokalizacji. Empiryczne dystrybuanty błędów zostały przedstawione na Rys. 5. W przypadku obydwu testowanych metod, maksymalny błąd lokalizacji nie przekroczył 1,1 m. Dla zaproponowanej metody, średni błąd wynosi 0,36 m i jest znacznie mniejszy niż w przypadku zastosowania konwencjonalnego filtra cząsteczkowego (0,52 m).



Rysunek 5: Empiryczne dystrybuanty błędu lokalizacji

4. PODSUMOWANIE

W referacie przedstawiono metodę lokalizacji przeznaczoną do zastosowania w ultraszerokopasmowych systemach lokalizacyjnych. Metoda, oprócz pomiarów wykonywanych w interfejsie radiowym wykorzystuje informacje dotyczące aktywności wykonywanej przez użytkownika. Detekcja aktywności jest przeprowadzana na podstawie pomiarów przyspieszenia za pomocą klasyfikatora opartego na spłotowej sieci neuronowej.

Wyniki badań eksperymentalnych pokazały, że uwzględnienie dodatkowej informacji na temat kontekstu lokalizacji pozwala na zwiększenie dokładności wyznaczania położenia użytkownika. Średni błąd lokalizacji w porównaniu do zastosowania konwencjonalnego filtra cząsteczkowego był mniejszy o kilkanaście centymetrów.

Skuteczność zaproponowanej metody można dodatkowo zwiększyć poprzez uwzględnienie innych typów aktywności np. wchodzenie po schodach lub otwieranie drzwi. Nie przeprowadzono jeszcze badań w tym zakresie.

W referacie przedstawiono wyniki prac realizowanych w ramach projektu finansowanego przez Narodowe Centrum Badań i Rozwoju w ramach programu AAL Call 2021 nr umowy AAL/AALCall2021/52/CAREUP/2022.

LITERATURA

- [1] M. Kołakowski, 2020, "Redukcja wpływu ciała użytkownika na dokładność lokalizacji z wykorzystaniem hybrydowego algorytmu lokalizacyjnego," *Przegląd Telekomunikacyjny - Wiadomości Telekomunikacyjne* (7-8), 312–315, DOI: 10.15199/59.2020.7-8.39
- [2] G. Pipelidis i inni, 2019 "A Novel Lightweight Particle Filter for Indoor Localization," 2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN), (Pisa, Włochy), 1–8, DOI: 10.1109/IPIN.2019.8911744
- [3] R. Jackermeier i B. Ludwig, 2019, "Door Transition Detection for Long-Term Stability in Pedestrian Indoor Positioning," 2019 International Conference on Indoor Positioning and Indoor Navigation (IPIN), (Pisa, Włochy), 1–8, DOI: 10.1109/IPIN.2019.8911810.
- [4] Zawar Hussain, Michael Sheng, Wei Emma Zhang, 2019. "Different Approaches for Human Activity Recognition: A Survey," DOI: 10.48550/arXiv.1906.05074.
- [5] Akram Bayat, 2014, "A Study on Human Activity Recognition Using Accelerometer Data from Smartphones," DOI: 10.1016/j.procs.2014.07.009.
- [6] Oscar D. Lara, Miguel A. Labrador, 2013, "A survey on human activity recognition using wearable sensors," DOI: 10.1109/SURV.2012.110112.00192.
- [7] Jindong Wang, Yiqiang Chen, Shuji Hao, Xiaohui Peng, Lisha Hu, 2019. "Deep learning for sensor-based activity recognition: A survey," DOI: 10.1016/j.patrec.2018.02.010.
- [8] Anna Ferrari, Daniela Micucci, Marco Mobilio, Paolo Napolitano, 2019, "Human Activities Recognition Using Accelerometer and Gyroscope," DOI: 10.1007/978-3-030-34255-5_28.
- [9] Wenchao Jiang, Zhaozheng Yin, 2015 "Human Activity Recognition Using Wearable Sensors by Deep Convolutional Neural Networks," DOI: 10.1145/2733373.2806333.
- [10] Charissa Ann Ronao, Sung-Bae Cho, 2016 "Human activity recognition with smartphone sensors using deep learning neural networks," DOI: 10.1016/j.eswa.2016.04.032.
- [11] Abdulmajid Murad, Jae-Young Pyun, 2017 "Deep Recurrent Neural Networks for Human Activity Recognition," DOI: 10.3390/s17112556.
- [12] J. Kołakowski i inni, 2020, "UWB/BLE Tracking System for Elderly People Monitoring," *Sensors*, 20, 1574, DOI: 10.3390/s20061574